

pandas安装

conda install pandas	获得 pandas 的最佳方式是通过 conda
python3 -m pip install --upgrade pandas	通过 PyPI
pip install -i https://pypi.tuna.tsinghua.edu.cn/simple gevent	使用清华镜像安装

国内推荐使用清华镜像安装

关键缩写和包导入

df	任意的Pandas DataFrame对象
s	任意的Pandas Series对象

缩写

引入方法

import pandas as pd	导入pandas并缩写为pd
---------------------	----------------

import numpy as np	导入numpy并缩写为np
--------------------	---------------

常规导入

数据选取

df[col]	根据列名，并以Series的形式返回列
df[[col1, col2]]	以DataFrame形式返回多列
s.iloc[0]	按位置选取数据
s.loc['index_one']	按索引选取数据
df.iloc[0,:]	返回第一行
df.iloc[0,0]	返回第一列的第一个元素

数据清理

df.columns = ['a','b','c']	重命名列名
pd.isnull()	检查DataFrame对象中的空值，并返回一个Boolean数组
pd.notnull()	检查DataFrame对象中的非空值，并返回一个Boolean数组
df.dropna()	删除所有包含空值的行
df.dropna(axis=1)	删除所有包含空值的列
df.dropna(axis=-1,thresh=n)	删除所有小于n个非空值的行
df.fillna(x)	用x替换DataFrame对象中所有的空值
s.astype(float)	将Series中的数据类型更改为float类型
s.replace(1,'one')	用'one'代替所有等于1的值
s.replace([1,3],['one','three'])	用'one'代替1，用'three'代替3
df.rename(columns=lambda x: x + 1)	批量更改列名
df.rename(columns={'old_name': 'new_name'})	选择性更改列名
df.set_index('column_one')	更改索引列
df.rename(index=lambda x: x + 1)	批量重命名索引

导入数据

pd.read_csv(filename)	从CSV文件导入数据	1
pd.read_table(filename)	从限定分隔符的文本文件导入数据	2
pd.read_excel(filename)	从Excel文件导入数据	3
pd.read_sql(query, connection_object)	从SQL表/库导入数据	4
pd.read_json(json_string)	从JSON格式的字符串导入数据	5
pd.read_html(url)	解析URL、字符串或者HTML文件，抽取其中的tables表格	6
pd.read_clipboard()	从你的粘贴板获取内容，并传给read_table()	7
pd.DataFrame(dict)	从字典对象导入数据，Key是列名，Value是数据	8

网上爬取表格一般使用方法6和方法2

导出数据

1	df.to_csv(filename)	导出数据到CSV文件
2	df.to_excel(filename)	导出数据到Excel文件
3	df.to_sql(table_name, connection_object)	导出数据到SQL表



By **solider245**
cheatography.com/solider245/

Published 14th June, 2019.
 Last updated 14th June, 2019.
 Page 1 of 2.

Sponsored by **ApolloPad.com**
 Everyone has a novel in them. Finish Yours!
<https://apollopad.com>

导出数据 (cont)

4 df.to_json(filename) 以Json格式导出数据到文本文件

一般文件名需要加'' 不知道为什么这里没加

数据处理：Filter、Sort和GroupBy

df[df[col] > 0.5] 选择col列的值大于0.5的行

df.sort_values(-col1) 按照列col1排序数据，默认升序排列

df.sort_values(-col2, ascending=False) 按照列col1降序排列数据

df.sort_values([col1, col2], ascending=[True, False]) 先按列col1升序排列，后按col2降序排列数据

df.groupby(col) 返回一个按列col进行分组的Groupby对象

df.groupby([col1, col2]) 返回一个按多列进行分组的Groupby对象

df.groupby(col1)[col2] 返回按列col1进行分组后，列col2的均值

df.pivot_table(index=col1, values=[col2, col3], aggfunc=max) 创建一个按列col1进行分组，并计算col2和col3的最大值的数据透视表

df.groupby(col1).agg(np.mean) 返回按列col1分组的所有列的均值

数据处理：Filter、Sort和GroupBy (cont)

data.apply(np.mean) 对DataFrame中的每一列应用函数np.mean

data.apply(np.max, axis=1) 对DataFrame中的每一行应用函数np.max

创建测试对象

pd.DataFrame(np.random.rand(20, 5)) 创建20行5列的随机数组成的DataFrame对象

pd.Series(my_list) 从可迭代对象my_list创建一个Series对象

df.index = pd.date_range('1900/1/30', periods=df.shape[0]) 增加一个日期索引

查看、检查数据

df.head(n) 查看DataFrame对象的前n行

df.tail(n) 查看DataFrame对象的最后n行

df.shape() 查看行数和列数

df.info() 查看索引、数据类型和内存信息

df.describe() 查看数值型列的汇总统计

s.value_counts(dropna=False) 查看Series对象的唯一值和计数

df.apply(pd.Series.value_counts) 查看DataFrame对象中每一列的唯一值和计数

数据合并

df1.append(df2) 将df2中的行添加到df1的尾部

df.concat([df1, df2], axis=1) 将df2中的列添加到df1的尾部

df1.join(df2, on=col1, how='inner') 对df1的列和df2的列执行SQL形式的join

数据统计

df.describe() 查看数据值列的汇总统计

df.mean() 返回所有列的均值

df.corr() 返回列与列之间的相关系数

df.count() 返回每一列中的非空值的个数

df.max() 返回每一列的最大值

df.min() 返回每一列的最小值

df.median() 返回每一列的中位数

df.std() 返回每一列的标准差